

SEGMENTAÇÃO DE IMAGENS DE MAMOGRAFIAS DIGITAIS

Trabalho de Conclusão de Curso

Engenharia da Computação

Angélica Alcoforado Mascaro

Orientador: Prof. Carlos Alexandre Barros de Mello

Co-Orientador: Prof. Wellington Pinheiro dos Santos

Recife, dezembro de 2007



UNIVERSIDADE
DE PERNAMBUCO

SEGMENTAÇÃO DE IMAGENS DE MAMOGRAFIAS DIGITAIS

Trabalho de Conclusão de Curso

Engenharia da Computação

Este Projeto é apresentado como requisito parcial para obtenção do diploma de Bacharel em Engenharia da Computação pela Escola Politécnica de Pernambuco – Universidade de Pernambuco.

Angélica Alcoforado Mascaro

Orientador: Prof. Carlos Alexandre Barros de Mello

Co-Orientador: Prof. Wellington Pinheiro dos Santos

Recife, dezembro de 2007



UNIVERSIDADE
DE PERNAMBUCO

Angélica Alcoforado Mascaro

SEGMENTAÇÃO DE IMAGENS DE MAMOGRAFIAS DIGITAIS

Resumo

O câncer de mama é uma doença de alta incidência nos países ocidentais e a análise de mamografias é uma tarefa difícil mesmo para os profissionais mais experientes. Diversos estudos têm sido desenvolvidos atualmente na busca por algoritmos que ajudem a encontrar evidências de células cancerígenas em mamografias.

Neste trabalho, uma variação de um índice de fidelidade é usada visando à segmentação e classificação de mamografias utilizando um descritor de texturas: o histograma da soma. O processo constitui-se de duas etapas: na primeira delas, é feita a identificação do filme e dos limites da mama, sendo útil para isolar a área a ser analisada na busca por doenças; a segunda etapa consiste em segmentar e classificar a região da mama em termos de seus tecidos mamários.

Outros descritores de textura também são usados junto com o índice de fidelidade: o LBP (*Local Binary Pattern*) e a GLCM (*Gray Level Co-Occurrence Matrix*). Eles foram testados na segmentação dos tecidos mamários e uma variação foi proposta para o LBP.

Uma forma de auxiliar os radiologistas durante o diagnóstico está no desenvolvimento de algoritmos para classificação de doenças de acordo com seu grau de risco. Nesse sentido, experimentos são realizados envolvendo a comparação entre imagens contendo lesões mamárias através do índice de fidelidade e os seus resultados são apresentados.

Por fim, o desempenho dos Mapas Auto-Organizáveis de Kohonen (SOM) e do algoritmo de agrupamento K-Médias é avaliado para fins de segmentação de mamografias, comparando com os resultados das outras técnicas. Com isso a delimitação de regiões pode ser verificada através de uma abordagem pixel-a-pixel.

Abstract

The breast cancer is a high incidence disease in the Western countries and analysis of mammograms it's a hard task even for professionals with lot of experience. Several studies are being developed nowadays in the search for algorithms to help finding evidences of cancerous cells in a mammogram.

In this work, a variation of a fidelity index is used aiming the segmentation and classification of mammograms using a texture descriptor: the sum histogram. The process consisted of two stages: the first of them, the identification of the film and the breast limits is performed, useful to isolate the area to be analyzed in the search for diseases; the second stage consisted of segment and classify the region of the breast in the terms of breast tissues.

Another texture descriptors are also used jointly with the fidelity index: the LBP (*Local Binary Pattern*) and the GLCM (*Gray Level Co-Occurrence Matrix*). They are tested in the segmentation of the breast tissues and a variation is proposed for the LBP.

The development of algorithms to classify diseases according to the level of its risk can be helpful to radiologists during the diagnosis. In this way, experiments are developed comparing images containing breast lesions through the use of the fidelity index and the results of these experiments are presented herein.

Finally, the performance of the Kohonen's Self-Organizing Maps (SOM) and the K-Means clustering algorithm is evaluated for mammogram segmentation purposes. The delimitation of the regions can then be verified through a pixel-to-pixel approach.

Sumário

| | |
|---|------------|
| Índice de Figuras | iv |
| Índice de Tabelas | vi |
| Tabela de Siglas | vii |
| 1 Introdução | 9 |
| 1.1 Organização do Trabalho | 10 |
| 2 Mamografias | 11 |
| 2.1 Anatomia, histologia e patologias das mamas | 12 |
| 2.2 A obtenção da imagem mamográfica | 13 |
| 3 Análise de Texturas | 16 |
| 3.1 Descritores de Textura | 17 |
| 3.1.1 Matriz de Co-Ocorrência de Tons de Cinza (GLCM - <i>Gray Level Co-Occurrence Matrix</i>) | 18 |
| 3.1.2 Histograma da Soma/Diferença (SDH – <i>Sum/Difference Histogram</i>) | 18 |
| 3.1.3 LBP - <i>Local Binary Pattern</i> | 19 |
| 3.2 Aplicação: Comparação entre Texturas | 20 |
| 4 Experimentos e Resultados | 23 |
| 4.1 O novo índice de fidelidade | 23 |
| 4.2 Segmentação do filme e da borda da mama | 25 |
| 4.3 Segmentação dos tecidos mamários | 28 |
| 4.3.1 Testes com amostras de doenças | 31 |
| 4.3.2 Testes com uso do LBP | 33 |
| 4.3.3 Testes com uso da GLCM | 35 |
| 4.4 Testes com redes neurais de aprendizado não-supervisionado | 35 |
| 5 Conclusões e Trabalhos Futuros | 39 |
| 5.1 Contribuições | 39 |
| 5.2 Trabalhos Futuros | 41 |

Índice de Figuras

| | |
|---|----|
| Figura 1. Anatomia da mama. Em (a) principais aspectos da anatomia da mama. Em (b) uma mamografia apresentando alguns desses aspectos. | 12 |
| Figura 2. Diferença nas mamografias: em (a) imagem clara de paciente jovem e em (b) imagem escura de paciente mais idosa. | 12 |
| Figura 3. Doenças na mama: em (a) tumor maligno. Em (b) região da mamografia com presença de <i>cluster</i> de calcificação. | 13 |
| Figura 4. Esquema do raio-x atravessando a mama durante uma mamografia. | 14 |
| Figura 5. Seção do corte da mama. | 14 |
| Figura 6. Esquemas ilustrando radiação extra-focal (a) e radiação espalhada (b) | 15 |
| Figura 7. Exemplos de Texturas: (a) concreto, (b) madeira e (c) pedra. | 16 |
| Figura 8. GLCM: à direita a matriz de co-ocorrência é preenchida indicando quantas vezes a cor i e a cor j estão presentes na imagem (à esquerda) separados por uma distância d igual a 1. | 18 |
| Figura 9. Exemplo de varredura da imagem para geração do histograma da soma com deslocamentos $dx=dy=2$. | 19 |
| Figura 10. Obtenção do LBP. Em (a) a imagem original. Em (b) uma matriz binária após comparação com pixel central. Em (c) a matriz utilizada na multiplicar as respectivas células dos valores encontrados em (b). E em (d) o resultado dessa multiplicação. | 19 |
| Figura 11. Em (a) imagem original e suas diferentes versões de padrão de JPEG com (b) 15% de perda, (c) 30%, (d) 80% e (e) 90% de perda sobre imagem com 80% de perda. | 21 |
| Figura 12. Em (a) textura original, (b) Textura sintética e em (c) imagem das flores que foi considerada mais similar à textura original do que a própria textura sintética. | 22 |
| Figura 13. Exemplos de diferentes conjuntos de texturas usados na avaliação desse novo índice de fidelidade. | 24 |
| Figura 14. (a) Imagem “mdb014” da base Mini-MIAS, (b) imagem segmentada através do uso do índice de fidelidade e (c) esquema dos arcos que delimitam as regiões atravessadas pela radiação. | 25 |
| Figura 15. Mamografia com região da borda da mama eliminada: (a) Imagem resultante da segmentação e (b) imagem final com borda eliminada. | 26 |
| Figura 16. Em (a) imagem mdb030 original e em (b) a mesma imagem segmentada. Região do filme identificada com mais de uma cor devido à radiação extra-focal alta. | 27 |
| Figura 17. Exemplos de limiarização global aplicada às imagens da base Mini-MIAS. A imagem mdb030 em (a) foi limiarizada em (b) com limiar igual a 10. A imagem mdb029 em (c) foi limiarizada em (d) com limiar igual a 5, mostrando os cuidados que devem ser tomados na limiarização já que, nessa imagem, muita informação foi perdida. | 27 |

- Figura 18.** Em (a) imagem mdb030 original. Em (b) imagem segmentada com filme identificado como mais de uma região. Em (c) limiar global igual a 10 separa o filme da região da mama. Em (d) imagem com filme homogêneo todo identificado como única cor. Em (e) imagem com borda da mama extraída. 28
- Figura 19.** Seleção de amostras dos tecidos nas mamografias. (a) mdb060 – amostra de tecido adiposo; (b) mdb50 – amostra de tecido glandular e (c) mdb172 – amostra de tecido glandular denso. 29
- Figura 20.** Exemplos da segmentação da mamografia em tecidos adiposo, glandular, e glandular denso. 30
- Figura 21.** Anomalias presentes em mamografias divididas em 6 classes da base mini-MIAS 31
- Figura 22.** (a) Imagem mdb002 e (b) resultado da segmentação utilizando o LBP. 33
- Figura 23.** Novas matrizes de pesos do LBP. Em (a) matriz original e em (b), (c) e (d) as matrizes rotacionadas. 33
- Figura 24.** Cálculo do LBP com as novas matrizes. 34
- Figura 25.** Experimentos utilizando o índice de fidelidade aplicado ao LBP com 4 matrizes rotacionadas e janelas de 20x20 pixels. Em (a) imagem original mdb002. Em (b) LBP somado ao pixel central e em (c) somado à média dos 9 pixels da janela. 34
- Figura 26.** Resultado da aplicação do índice de fidelidade à matriz GLCM na imagem mdb002 com janelas de 20x20 pixels. 35
- Figura 27.** Resultados da segmentação de mamografias utilizando os mapas auto-organizáveis de Kohonen: em (a) imagem mdb001 original. Em (b) a segmentação com 5 classes, em (c) com 10 classes e em (d) com 25 classes. O número de iterações e a taxa de aprendizado foram fixados em 50 e 0,1, respectivamente. 36
- Figura 28.** Segmentação de tumores através de rede SOM: (a) Tumor benigno da classe CIRC; (b) 5 classes; (c) Tumor maligno da classe SPIC e (d) 5 classes. 37
- Figura 29.** Conjunto de dados de entrada rotulado em duas classes definindo-se $k = 2$. 37
- Figura 30.** Exemplos de aplicação do algoritmo K-Médias às imagens de mamografias utilizando 15 classes, 50 iterações e taxa de aprendizado igual a 0,1. (a) Imagem mdb003 e (b) 15 classes encontradas para essa imagem; (c) imagem mdb005 e (d) as 15 classes encontradas para essa imagem. 38

Índice de Tabelas

| | |
|---|----|
| Tabela 1. Valores do Índice de Z. Wang para as imagens da Figura 11. | 21 |
| Tabela 2. Índices de fidelidade aplicados entre as amostras de textura da Figura 13. | 24 |
| Tabela 3. Resultados do novo índice de fidelidade para as imagens da Figura 11. | 25 |
| Tabela 4. Comparações entre amostras de uma mesma classe, onde CALC = calcificações; ARCH = Distorção arquitetural; ASYM = assimétrico; MISC = outros ou sem definição; CIRC = circunscrito; SPIC: “espículado”. | 32 |
| Tabela 5. Comparação de amostras entre classes, onde CALC = calcificações; ARCH = Distorção arquitetural; ASYM = assimétrico; MISC = outros ou sem definição; CIRC = circunscrito; SPIC: “espículado”. | 32 |

Tabela de Siglas

(Dispostos em ordem alfabética)

CAD - Computer-Aided Diagnosis

CBIR - Content Based Image Retrieval (Recuperação de Imagens Baseada em Conteúdo)

GLCM - Grey Level Co-occurrence Matrix (Matriz de Co-Ocorrência de Tons de Cinza)

LBP - Local Binary Pattern (Padrão Binário Local)

RNA – Redes Neurais Artificiais

SDH - Sum/Difference Histogram (Histograma da Soma e Diferença)

SOM - Self Organized Maps (Mapas Auto-Organizáveis)

Agradecimentos

Ao Prof. Carlos Alexandre, obrigada pela orientação impecável, apoio constante e atenção durante todo o período de construção deste Trabalho de Conclusão.

Ao Prof. Wellington Pinheiro, muito obrigada pelo auxílio e contribuição concedidos na co-orientação deste Trabalho.

A Camila, pela ajuda direta em algumas atividades. Sempre gentil e com boa vontade.

Aos amigos da Poli, por conseguirem adicionar bom humor mesmo durante a correria deste período de conclusão de curso.

Aos amigos da AiLeader, meu muito obrigada pelas dicas e ajuda na solução de problemas.

Aos meus pais e à família, pelo carinho, bolsas de água quente para tendinite e preocupação com meu sucesso e bem estar.

A Tiago, pela atenção constante, carinho, cuidados, motivação e apoio em absolutamente todos os momentos.

Obrigada a todos!

Capítulo 1

Introdução

A mamografia é um exame da mama amplamente utilizado com o objetivo de diagnosticar precocemente o câncer de mama, quando as chances de um tratamento bem sucedido são bem maiores. Entre as mulheres, esse é o câncer mais comum e também a segunda causa de morte por câncer [1].

Embora a mamografia apareça nesse cenário como o principal método de auxílio ao diagnóstico do câncer de mama, esse exame não é perfeito e a análise desse tipo de imagem é uma tarefa bastante difícil. Essa dificuldade ocorre devido a vários fatores, tais como a grande variedade dos formatos das lesões, variação na densidade do tecido mamário e a alta taxa de ruído presente nas mamografias. Além disso, a própria natureza do problema é um complicador, já que as mamografias são representações bidimensionais de estruturas tridimensionais, resultando em sobreposição de regiões. Tudo isso resulta em um alto número de lesões não identificadas.

Ainda hoje, a experiência do radiologista em interpretar corretamente a informação presente na mamografia é uma parte fundamental no processo. Por ser um aspecto não-quantitativo, não é fácil medir quanta experiência é necessária para um diagnóstico correto, nem sequer estão claros quais os aspectos usados nessa classificação [2]. Em casos de dúvida, a atitude do radiologista tende a ser muito cautelosa, prescrevendo uma análise através de um método invasivo como uma biópsia. A consequência disso é o grande número de resultados de biópsias que não apontam doenças [3].

CADs (*Computer-Aided Diagnosis*) são ferramentas de apoio aos radiologistas através do computador que têm sido desenvolvidas para melhorar o desempenho da análise de mamografias. Elas podem ser úteis de várias maneiras e diversos estudos têm sido desenvolvidos atualmente nesse sentido. As contribuições desses trabalhos envolvem identificação de lesões presentes na imagem [4], classificação de regiões ou de objetos de interesse (como os tumores ou as calcificações) [3,5,6], ou ainda a exibição de um histórico de casos com características semelhantes ao de uma paciente em questão [7]. Um ponto importante a ser destacado é que, por lidarem com vidas humanas, a taxa de erro desses sistemas deve ser muito baixa. Aliada à complexidade natural do problema e a interdisciplinaridade, isso torna a análise de mamografias um desafio ao Processamento de Imagens.

Muitas das técnicas que estão sendo desenvolvidas para análise de mamografias fazem uso de atributos de textura [3-6,8]. A análise através de texturas é útil em algumas aplicações por se aproximar da avaliação feita pelo sistema visual humano. Cada textura possui um padrão de cores característico. A caracterização desse padrão de cores é uma tarefa difícil, em que uma dada

técnica pode não ser ideal para todos os casos. No caso de imagens mamográficas, atributos de texturas podem fornecer uma descrição do tecido mamário, sendo uma boa maneira de descrever tais regiões. Elas podem ainda ser úteis na caracterização de anomalias.

Nesse contexto, um dos objetivos deste trabalho é fazer a análise de imagens mamográficas em termos de texturas. Essa análise é feita através de comparação de imagens, com uso de um índice de fidelidade. Um índice de fidelidade avalia a similaridade entre duas imagens. Em [9], é proposto por Z.Wang *et al* um novo índice de fidelidade que tem resultados significantes quando avalia distorções do tipo impostas por perda de padrão de arquivo JPEG. No entanto, da forma como foi definido, o índice não é apropriado para análise de texturas. Nesse caso, uma variação proposta [8], que utiliza um descritor de textura, (o Histograma da Soma) foi utilizada, atendendo bem ao propósito da comparação entre texturas. Neste trabalho será apresentado também como tal índice foi usado para segmentar e classificar uma mamografia.

Em uma primeira fase, a utilização do índice modificado dentro de uma mesma imagem permitiu a identificação da “borda da mama”. Essa identificação é usada nesse trabalho para extração confiável da região de interesse da mama, excluindo o filme.

Numa segunda fase, esse mesmo índice é usado na segmentação de mamografias em seus tecidos mamários. Isso foi feito através da criação de um banco de imagens com amostras de tecidos para comparação com as diversas regiões da mamografia. Vários testes foram realizados para ajuste dos algoritmos. Outros testes envolveram a inclusão de amostras de doenças no banco criado. Ainda, foi analisada a comparação entre essas imagens de doenças.

Outra forma de descrever as texturas da imagem também foi testada, utilizando outros dois descritores de textura: o LBP (*Local Binary Pattern*) e a GLCM (*Gray Level Co-Occurrence Matrix*). Essas aplicações serão mostradas neste trabalho juntamente com uma modificação proposta ao LBP e seus respectivos resultados.

Por fim, este trabalho contemplou a aplicação de redes neurais na segmentação das mamografias. Duas redes de aprendizado não-supervisionado foram avaliadas: os Mapas Auto-Organizáveis de Kohonen (SOM – *Self Organized Maps*) e o algoritmo de agrupamento K-Médias. O desempenho de cada uma delas é apresentado.

Parte deste trabalho foi publicada pela autora em um artigo científico em [8] na Conferência Latino-Americana de Informática, realizada no Chile em 2006 (CLEI 2006).

1.1 Organização do Trabalho

Este trabalho está organizado em 5 Capítulos. Neste Capítulo 1, estão expostas as motivações e objetivos do trabalho. No Capítulo 2, são apresentados alguns dos principais aspectos relativos às mamografias, abrangendo conceitos sobre anatomia, histologia e patologias das mamas além de considerações sobre o processo de obtenção da imagem mamográfica.

O Capítulo 3 aborda a análise de texturas através do computador. São expostos métodos de se descrever texturas e a diferença entre uma comparação entre imagens genericamente e uma comparação entre texturas.

No Capítulo 4, é mostrado um conjunto de experimentos e resultados relacionados ao uso do índice de fidelidade de Z.Wang modificado com aplicação em mamografias. Esses experimentos envolvem a segmentação de mamografias com identificação da borda da mama e, posteriormente, com identificação dos tecidos. Resultados de testes com uso do LBP, do GLCM e de redes neurais de aprendizado não-supervisionado também são discutidos.

Por fim, o Capítulo 5 expõe conclusões e discute propostas de trabalhos futuros à esta monografia.

Capítulo 2

Mamografias

De acordo com a Sociedade Americana de Câncer (*American Cancer Society*) [1] são esperados mais de 170 mil novos casos de câncer de mama entre as mulheres nos Estados Unidos e uma estimativa de mais de 40 mil mortes por câncer de mama em 2007. Ficando atrás apenas do câncer de pulmão, o câncer de mama é a segunda grande causa de morte por câncer. De acordo com o INCA (Instituto Nacional de Câncer) [10], entre 2006 e 2007, 50 mil novos casos desse tipo de câncer serão diagnosticados no Brasil.

A mamografia é um raio-x da mama capaz de detectar lesões ainda muito pequenas (de milímetros). Este exame permite o diagnóstico do câncer de mama nos seus primeiros estágios, quando ainda é possível a cura através de tratamento. As chances de cura a partir de um diagnóstico precoce são de 98% [10].

Uma anormalidade pode ser detectada numa mamografia quando ela ainda não pode ser sentida pela mulher. O benefício do uso da mamografia é evidenciado pela redução de casos de morte desde os anos 90 pela combinação de rápida detecção e tratamento [1].

Por esses motivos, grande esforço tem sido empregado no desenvolvimento de sistemas computacionais capazes de auxiliar de alguma forma no diagnóstico do câncer de mama [2-14]. As Ferramentas CAD (*Computer-Aided Diagnosis*) [7] são ferramentas que auxiliam no diagnóstico através do computador. Elas podem ser extremamente úteis na decisão de casos suspeitos, servindo como uma “segunda leitura”.

Pesquisas mostram que o uso de ferramentas CAD tem se tornado uma prática bem aceita pelos radiologistas na identificação de calcificações, melhorando substancialmente a eficiência dos radiologistas quando interpretam uma mamografia [13,12 *apud* 7]. No entanto, a sensibilidade das CADs para identificação de massas e as altas taxas de falsos positivos reduz a confiabilidade dos radiologistas nas CADs com esse propósito.

Uma ferramenta CAD pode, dentre outras coisas, disponibilizar um histórico de casos semelhantes ao da paciente em questão. Por exemplo, dado um novo caso clínico a ser avaliado, uma ferramenta CAD pode fazer uma consulta em uma biblioteca de referência para buscar outros casos semelhantes já diagnosticados previamente. A exemplo disso, Zheng *et al* [7], apresenta uma ferramenta ICAD (*interactive CAD*) que foi desenvolvida com o objetivo de encontrar lesões semelhantes em imagens de mamografias.

2.1 Anatomia, histologia e patologias das mamas

As mamas são, em essência, uma coleção de tecidos que foram adaptados para secretar leite após o parto da mulher. As glândulas que produzem leite são chamadas lóbulos e os tubos que conectam eles aos mamilos são chamados dutos. A Figura 1 apresenta um esboço dos principais aspectos da anatomia da mama (Figura 1.a). Em (b) estão apresentados alguns desses aspectos em uma mamografia.

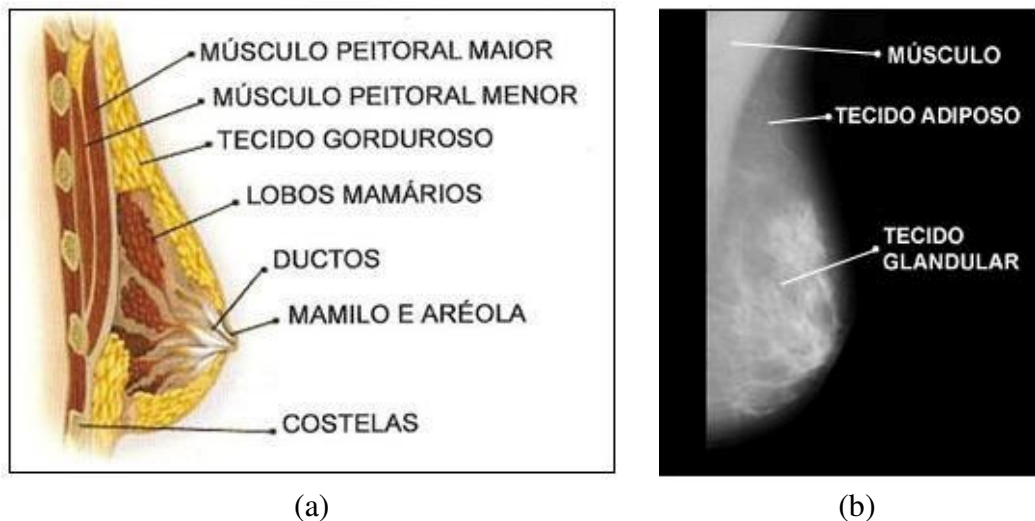


Figura 1. Anatomia da mama. Em (a) principais aspectos da anatomia da mama. Em (b) uma mamografia apresentando alguns desses aspectos.

Basicamente, uma mama normal consiste de tecidos adiposo, glandular e fibroso, às vezes calcificações (um tipo de lesão comum, que não necessariamente é indicativo de doença).

Com o avançar da idade, grande parte do tecido mamário da mulher é convertido em gordura (tecido adiposo). A gordura, por sua vez, aparece escura no raio-x. Por esse motivo, a definição da imagem da mamografia em mulheres com menos de 35 anos é prejudicada, devido à maior da densidade do órgão. A Figura 2 exhibe a diferença entre as mamografias de pacientes jovem (a) e mais idosa (b). Em (a), a imagem muito clara dificulta muito a identificação de doenças [11].




Figura 2. Diferença nas mamografias: em (a) imagem clara de paciente jovem e em (b) imagem escura de paciente mais idosa.

‘Câncer’ é o nome de um grupo de doenças nas quais as células do corpo são alteradas na aparência e função. Tais células anormais podem crescer fora do controle e formar uma massa

ou ‘tumor’. Quando células anormais nascem no tecido mamário, a massa é chamada um tumor mamário.

Um tumor mamário é considerado benigno se é limitado a pequenas camadas de célula e não ultrapassa tecidos vizinhos ou órgãos. Mas se o tumor se espalha para tecidos vizinhos ou órgãos, ele é considerado maligno. A Figura 3a exibe um exemplo de tumor maligno.

Um tipo de lesão muito comum em mamografias são as microcalcificações. As microcalcificações são depósitos de cálcio em formato de grânulos que ocorrem como resultado de secreções dentro de estruturas que se tornaram espessas e secas. Isso ocorre devido à especialização dos tecidos da mama na produção de leite o qual é rico em cálcio. Quando são indicativos de câncer, as calcificações freqüentemente aparecem em *clusters*, como ilustrado na Figura 3b.

Cerca de 30 a 50% das lesões não-palpáveis são detectadas pela presença de calcificações [11], sendo a sua identificação na mamografia de fundamental importância para a detecção precoce do câncer de mama. Por isso, vários trabalhos têm sido apresentados a respeito da análise e classificação via computador de calcificações [3,14]. Elas assumem diferentes formas e há sempre uma correlação entre a forma e distribuição das microcalcificações e o diagnóstico do câncer [11].




Figura 3. Doenças na mama: em (a) tumor maligno. Em (b) região da mamografia com presença de *cluster* de calcificação.

Isso também ocorre para o caso dos tumores (ou nódulos) encontrados. O formato dos nódulos é um indicativo do seu grau de risco, sendo aqueles de formato irregular ou “espiculado” (espinhado) os que apresentam maiores chances de serem malignos. No entanto, casos malignos também podem apresentar contornos bem definidos. Por isso, a importância da identificação do contorno dos nódulos, sendo uma tarefa de rotina para os radiologistas.

2.2 A obtenção da imagem mamográfica

Além da dificuldade devido à sobreposição de tecidos e variedade de formas das doenças, a análise de mamografias é prejudicada pela alta taxa de ruído nesse tipo de exame. Por esse motivo, há uma taxa alta de casos de doenças que não são detectados pelo radiologista.

O estudo do processo de obtenção da imagem mamográfica permite entender melhor algumas particularidades desse tipo de exame (como ruídos e formação da imagem) levando à construção de algoritmos de processamento de imagem mais confiáveis.

Cada tecido mamário atenua o feixe de fótons do raio-x de forma mais ou menos intensa. Por exemplo, o tecido adiposo atenua pouco o raio-x, já as calcificações atenuam bastante o raio. Quanto menor for a atenuação do feixe de fótons, maior será a exposição ao filme (onde se forma a imagem) e mais escuro ele se torna. Por esse motivo as mamografias de mulheres mais velhas

são mais escuras, devido a maior presença de tecido adiposo que atenua pouco o raio-x. Já as calcificações aparecem como pequenos pontos brancos na imagem. Os tecidos fibroso, glandular e canceroso atenuam igualmente o raio, de forma que não é possível distingui-los apenas em termos de cor na imagem.

A Figura 4 apresenta um esquema do sistema de obtenção das imagens de mamografias.




Figura 4. Esquema do raio-x atravessando a mama durante uma mamografia.

A partir da Figura 4 é possível fazer a seguinte análise:

- Arco E: passa na borda da mama; O raio-x tangencia a mama antes de atingir 'E'; há bem pouca atenuação dos raios;
- Arco D: Há espessura maior de tecido que em 'E', mas ainda pouca atenuação, já que é a 'borda da mama';
- Arco C: Há H cm de gordura; grande atenuação, porém uniforme.
- Arcos A e B: Mistura heterogênea de tecidos.

Pode-se observar que a partir de E os raios vão gradativamente atravessando uma maior quantidade de tecido, até atingir C. A "borda da mama", ilustrada na Figura 5 é justamente a região delimitada pelos arcos C e E. É uma região composta praticamente de gordura onde a espessura da mama gradativamente é reduzida até zero.



Figura 5. Seção do corte da mama.

A identificação dessa região na mamografia pode ser usada no processo de extração do plano de fundo (filme) na imagem de forma mais confiável que métodos baseados em limiar (*threshoding*), como apresentado em Aylward [15]. Pode ainda servir como base para estimar a espessura da mama e, também, para estimar a quantidade de radiação "extra-focal", um tipo de ruído responsável por 15% de toda a radiação da mamografia [11].

A radiação extra-focal, ilustrada na Figura 6a, é composta por número considerável de fótons que deixam o tubo de raio-x por outros pontos (sem ser pelo foco).

Um outro tipo de ruído existente em mamografias é devido à “radiação espalhada” (*scattered radiation*), ilustrada na Figura 6b. Este ruído é o maior fator de degradação das imagens mamográficas e ocorre porque alguns raios se espalham ao atravessar o tecido mamário. De toda a radiação que sai da mama, cerca de 40% de toda a radiação é radiação espalhada [11].




Figura 6. Esquemas ilustrando radiação extra-focal (a) e radiação espalhada (b).

Como visto neste capítulo, a análise de mamografias é uma tarefa difícil mesmo para os especialistas da área. A alta taxa de ruído, a variedade dos formatos dos elementos de interesse, a sobreposição de tecidos dentre outras dificuldades comprometem o diagnóstico.

Por esses motivos, grande esforço tem sido empregado para que a análise de mamografias via computador melhore a eficiência dos radiologistas na interpretação de mamografias. Várias técnicas têm sido propostas para detecção automática e classificação de doenças e em grande parte delas, o uso de atributos de texturas está presente como uma boa maneira de avaliar as regiões da imagem. O Capítulo a seguir fala exatamente sobre a análise de texturas.

Capítulo 3

Análise de Texturas

Texturas ainda não têm um conceito completamente definido, mas podemos interpretá-las como um padrão de cores usado pelo sistema visual humano para reconhecer a forma e de que é feito um objeto. A Figura 7 apresenta alguns exemplos de texturas. A partir deles é possível ter uma idéia exata de qual material cada imagem foi retirada. Texturas ajudam o sistema visual humano a reconhecer objetos, sendo fundamentais no perfeito entendimento de uma cena. São ainda amplamente usadas em Computação Gráfica para dar mais naturalidade às cenas criadas.




Figura 7. Exemplos de Texturas: (a) concreto, (b) madeira e (c) pedra.

A análise de uma imagem em termos de suas texturas permite identificar regiões através desse padrão de cores. Com a análise de texturas é possível se ter uma medida geral de como ocorre o relacionamento entre os pixels de uma dada região.

A área de Visão Computacional lida com a classificação das texturas presentes em uma imagem ou na identificação de texturas semelhantes em um banco de imagens (TBIR – *Texture Based Image Retrieval*).

A análise de texturas está presente também em outras áreas do processamento gráfico. Em Processamento de Imagens, há pesquisas principalmente na busca por algoritmos que criem texturas automaticamente, a síntese de texturas. Essa síntese procura definir o padrão da textura e reproduzi-lo [16].

Haralick *et al* [17] definiu um conjunto de 14 atributos para definir uma textura. Embora antigo, esses atributos são ainda bastante utilizados até hoje [4-6]. São elas:

- Segundo Momento Angular
- Contraste
- Correlação

- Variância
- Momento de Diferença Inverso
- Média da Soma
- Variância da Soma
- Entropia da Soma
- Entropia
- Variância da Diferença
- Entropia da Diferença
- Medidas de Informação da Correlação (2 propriedades)
- Coeficiente de Correlação Máximo

Como exemplo de sua utilização, Wei *et al* [6] definiu uma medida de similaridade entre duas imagens baseada nessas propriedades de Haralick. Ele faz uma análise de quais propriedades são mais relevantes para uso na sua medida durante a comparação de regiões de lesões em mamografias.

Para aplicações em imagens médicas, a textura é uma característica crucial, que provê indicações da profundidade da cena e da distribuição espacial da variação dos tons de cinza [18 *apud* 6].

Em trabalhos com aplicações em mamografias, o uso de textura é muito presente [3-6,8]. Como a habilidade de interpretação do radiologista ainda é o fator mais importante na análise de mamografias, o uso de atributos de texturas também é útil por se aproximar da avaliação feita pelo sistema visual humano.

Nesse caso de imagens mamográficas, atributos de texturas podem nos trazer informações a respeito dos diferentes tecidos presentes na mama e de eventuais anormalidades. Para as regiões de tecidos próximas a alguma anomalia, essa análise, indiretamente, traz ainda informação sobre o processo biológico que produziu a anormalidade.

A presença de uma lesão mamária pode causar um distúrbio na homogeneidade dos tecidos, resultando em uma distorção arquitetural (*architectural distortion*) [19 *apud* 6].

Santo *et al* [3] reúne as principais características propostas na literatura para uso em mamografias e as utiliza para classificação de microcalcificações. Destas características, grande parte são atributos de textura. Isso é feito para que se tenha uma informação a respeito do tecido ao redor das calcificações e, indiretamente, da formação do tecido que produziu a microcalcificação.

Nesse sentido, observa-se o quanto a identificação dos tecidos na imagem pode ser útil e como o uso de atributos de textura é justificável nessa tarefa.

3.1 Descritores de Textura

Uma forma de representar as texturas é através do uso de *descritores de textura*, conforme apresentado a seguir. Os descritores de textura utilizam alguma informação da imagem para tentar representá-las. Alguns se apresentam na forma de matrizes, outros como histogramas modificados para tentar representar as imagens. Como exemplos, existem a Matriz de Co-ocorrência de Tons de Cinza (GLCM - *Grey Level Co-occurrence Matrix*), o LBP (*Local Binary Pattern*) e o Histograma da Soma e Diferença.

3.1.1 Matriz de Co-Ocorrência de Tons de Cinza (GLCM - *Gray Level Co-Occurrence Matrix*)

Esse descritor apresenta uma medida de probabilidade de ocorrência de cores separadas por uma dada distância em uma dada direção.

Para uma dada imagem, cada célula (i,j) da matriz de co-ocorrência funciona como um contador e armazena a frequência com que dois pixels ocorrem na imagem separados por uma distância d , um com a cor i , outro com a cor j , como mostrado na Figura 8. Nessa Figura, temos, à esquerda, uma imagem de exemplo onde aparecem em duas regiões da imagem as cores 1 e 2 separadas por um pixel de distância. Assim, se $d = 1$, a matriz GLCM tem sua posição $(1, 2)$ incrementada para 2, indicando a ocorrência de 2 pixels com cor 1 e 2 separados pela distância d .




Figura 8. GLCM: à direita a matriz de co-ocorrência é preenchida indicando quantas vezes a cor i e a cor j estão presentes na imagem (à esquerda) separados por uma distância d igual a 1.

A GLCM é uma matriz com $C \times C$ elementos, onde C é o número de diferentes tons que a imagem pode ter. Por exemplo, para uma imagem armazenada em 256 tons de cinza, a GLCM tem dimensão 256×256 . Isso traz uma grande desvantagem da GLCM: o grande espaço necessário para seu armazenamento. Além disso, uma imagem pode gerar uma matriz esparsa que é uma matriz com muitos valores iguais a zero. Outro problema na GLCM é o tempo de processamento necessário para seu cálculo. Por isso, outras medidas foram criadas.

3.1.2 Histograma da Soma/Diferença (SDH – *Sum/Difference Histogram*)

Esse segundo descritor, de forma semelhante à GLCM, observa o relacionamento entre os pixels e seus vizinhos separado por uma distância d . No entanto, a forma como armazena essa informação é bem diferente.

O *Histograma da soma* depende de deslocamentos dx e dy , e é o histograma das somas de todos os pixels separados por dx e dy . Como ilustrado na Figura 9, o *histograma da soma* varre a imagem e, para cada pixel na posição (i, j) , a sua cor é somada à do pixel da posição $(i+dx, j+dy)$ e a cor correspondente é incrementada no histograma. Com isso, em uma imagem em 256 tons de cinza, o histograma da soma vai de 0 a 510 (resultado da soma de 255 com 255).

Analogamente, o *Histograma da Diferença* calcula a diferença entre os pixels, variando seus valores de -255 a 255.

Nesse caso, há uma clara redução no espaço necessário para armazenamento do histograma em comparação com a GLCM. Aqui, para imagens com 256 cores, um vetor com 512 posições é suficiente para representar o SDH. No entanto, notadamente, a GLCM apresenta uma informação mais precisa sobre a distribuição de cores na textura original.




Figura 9. Exemplo de varredura da imagem para geração do histograma da soma com deslocamentos $dx=dy=2$.

3.1.3 LBP - Local Binary Pattern

No LBP [20], a descrição da textura é feita por um histograma representando o relacionamento local entre os pixels, como ilustrado na Figura 10.

Na imagem original em (a), o pixel central é utilizado como um limiar de comparação: a cor do pixel central (6) é comparada à cor de cada pixel ao seu redor. A seguir, uma matriz com valores binários é obtida em (b) indicando os resultados dessa comparação. Essa matriz recebe o valor binário ‘1’ nos elementos que têm valor maior que o pixel central e ‘0’ caso contrário. Em (c) é apresentada uma matriz de pesos utilizada para obtenção do LBP: a matriz binária obtida em (b) é multiplicada pelos valores das células correspondentes em (c), obtendo, então, a matriz (d). Os valores em (d) são então somados e o valor respectivo do histograma LBP é incrementado.




Figura 10. Obtenção do LBP. Em (a) a imagem original. Em (b) uma matriz binária após comparação com pixel central. Em (c) a matriz utilizada na multiplicar as respectivas células dos valores encontrados em (b). E em (d) o resultado dessa multiplicação.

Sendo assim, o “histograma LBP” varia de 0 a 255 (valor máximo alcançado quando todos os valores da matriz binária forem iguais a 1, gerando como resultado a soma dos valores da matriz de peso). No exemplo, o valor resultante será $1 + 8 + 32 + 128 = 169$. Então a posição 169 do histograma LBP deve então ser incrementada de 1.

O problema com esse descritor é que ele atribui um peso muito alto a algumas das posições da matriz de pesos. Por exemplo, quando um pixel referente ao peso ‘1’ for ativado, ele terá pouco impacto no valor do LBP final. Enquanto que o pixel referente ao peso ‘128’ terá grande impacto.

Além disso, esse descritor não traz nenhuma informação sobre as cores em si dos pixels, apenas do relacionamento entre eles. Isso pode ser útil ou não de acordo com a aplicação.

3.2 Aplicação: Comparação entre Texturas

Há várias formas de se fazer comparação entre imagens. Medidas matemáticas são atrativas porque informam em um valor a idéia geral sobre o quão parecidas são duas imagens. Por exemplo, PSNR (em dB) é calculada por:

$$PSNR = 10 \log\left(\frac{255^2}{MSE}\right) \quad (1)$$

onde MSE é o erro médio quadrático (*Mean Square Error*) representado pela raiz quadrada do somatório do quadrado dos erros pontuais, onde os erros pontuais, nesse caso, são representados pela diferença entre os pixels correspondentes nas duas imagens.

Essa é uma medida calculada pixel-a-pixel e não considera nenhuma informação estrutural da imagem. Por exemplo, o deslocamento de uma única coluna na imagem pode mudar completamente o resultado do PSNR gerando uma avaliação incorreta.

Baseado na idéia de que a principal função da visão humana é a de extrair informações estruturais das cenas, Zhou Wang [9] propôs um índice de fidelidade como medida de distorções estruturais entre duas imagens de forma a ser uma aproximação das distorções percebidas pelo Sistema Visual Humano.

O índice proposto por Z. Wang é definido como:

$$Q = \frac{\sigma_{xy}}{\sigma_x \sigma_y} \cdot \frac{2\bar{x}\bar{y}}{(\bar{x})^2 + (\bar{y})^2} \cdot \frac{2\sigma_x \sigma_y}{\sigma_x^2 + \sigma_y^2}, \quad (2)$$

sendo x a imagem original e y a imagem de teste, \bar{x} e \bar{y} são suas médias, σ_x e σ_y são suas variâncias e σ_{xy} é a correlação.

Esse índice modela qualquer distorção como uma combinação de três fatores: perda de correlação, distorção na luminância e distorção no contraste. A equação 2 apresenta o índice como um produto desses três fatores, respectivamente. O índice de Z. Wang varia de -1 a 1. Quanto mais o valor de Q se aproxima de 1 indica que as imagens são mais parecidas. Sendo 1 o caso em que as imagens são idênticas.

O índice de Z. Wang provê uma boa comparação entre imagens com alguns tipos de distorções. Ou seja, ele é apropriado para casos em que a imagem de teste é o resultado da aplicação de uma distorção à imagem original. Como exemplos de distorções em que o índice é representativo têm-se: ruído sal-e-pimenta, ruído Gaussiano e compressão de JPEG. A Figura 11 ilustra a aplicação do índice como medida da distorção causada na imagem do *cameraman* devido à aplicação de perda de padrão JPEG.




Figura 11. Em (a) imagem original e suas diferentes versões de padrão de JPEG com (b) 15% de perda, (c) 30%, (d) 80% e (e) 90% de perda sobre imagem com 80% de perda.

A Tabela 1 apresenta os valores do índice de Z.Wang ao comparar as imagens com perda à imagem original. Pode-se observar que os valores de Q representam bem a situação.

Tabela 1. Valores do Índice de Z.Wang para as imagens da Figura 11

| Imagem | Índice Q |
|-------------------------|----------|
| Cameraman 15% | 0,7991 |
| Cameraman 30% | 0,7239 |
| Cameraman 80% | 0,4924 |
| Cameraman 90% sobre 80% | 0,3976 |

Como mostrado na tabela, para as comparações entre a imagem original e as imagens com um baixo padrão de perda de JPEG, o índice Q apresentou valores mais altos, indicando que as imagens são mais semelhantes. À medida que a percentagem de perda foi aumentando os valores do índice foram decrescendo, representando a menor semelhança.

No entanto, o índice de Z.Wang tem aplicação restrita. Para casos em que a imagem de teste não é a própria imagem de referência após ter passado por algum processo de distorção o índice não apresenta bons resultados. Texturas se encaixam nesse tipo de situação.

Isto pode ser facilmente verificado num exemplo de geração automática de texturas apresentado na Figura 12. O exemplo apresenta uma textura original (12a) e a sua sintética (12b), além de uma imagem de flores (12c) visualmente sem nenhuma similaridade com as outras duas imagens. No entanto, a aplicação do índice de Z.Wang trouxe um resultado confuso: os valores

encontrados apontaram a imagem das flores como mais similar à textura original (12a) do que a própria textura sintética.




Figura 12. Em (a) textura original, (b) Textura sintética e em (c) imagem das flores que foi considerada mais similar à textura original do que a própria textura sintética.

Isso se deve ao fato dele não considerar nenhuma informação estrutural das imagens a serem comparadas além de não avaliar a distribuição de cores das imagens.

Uma modificação para resolver tal problema seria inserir esse tipo de informação através de um descritor de texturas. Esse é um dos focos do próximo Capítulo e será exposto junto com os resultados.

Capítulo 4

Experimentos e Resultados

Os experimentos realizados neste trabalho envolvem o uso de um novo índice de fidelidade criado a partir da aplicação do índice de Z.Wang em um descritor de textura – o histograma da soma, ao invés de usá-lo diretamente na imagem. O objetivo dessa modificação é justamente de ampliar o uso do índice para imagens de texturas, funcionando como uma boa medida de comparação entre imagens dessa natureza.

Os experimentos realizados envolveram a aplicação do índice proposto a imagens de mamografias digitais. O índice proposto foi utilizado para fazer a segmentação da imagem em duas etapas: primeiro para fazer a segmentação da região do filme da região de interesse, fazendo a identificação da borda da mama. Em uma segunda etapa, o mesmo índice foi utilizado na segmentação interna da mama, classificando-a nos diferentes tecidos mamários.

Durante essa etapa de identificação dos tecidos vários testes foram realizados para ajustar os parâmetros do algoritmo. Foram testados ainda outros descritores de textura, além do histograma da soma e outras modificações propostas para o uso do índice com o LBP.

Por fim, a terceira etapa dos experimentos envolveu a comparação da segmentação obtida através do índice modificado com a segmentação feita por redes neurais de aprendizado não supervisionado.

Para todos os testes, a base utilizada foi a MIAS MiniMammographic Database [21], composta por 322 imagens de mamografias.

Com exceção da Seção 4.4, a implementação dos algoritmos e testes descritos neste Capítulo foram todas realizadas no software Matlab [22].

4.1 O novo índice de fidelidade

Como descrito anteriormente, no Capítulo 3, o índice de Z.Wang não é satisfatório para a análise de alguns casos por não levar em consideração nenhuma informação estrutural das imagens a serem comparadas, nem sua distribuição de cores, tendo, por isso, aplicação muito limitada.

Para solucionar esse problema, adicionou-se ao índice uma nova informação: o histograma da soma [8]. Este descritor de textura possibilita a análise das imagens em termos de suas texturas, tornando o índice de Z.Wang mais apropriado para medir o nível de fidelidade entre imagens em diversas aplicações.

Para verificar a eficácia dessa variação proposta, o índice foi testado em várias imagens com amostras de texturas de papel e de madeira selecionadas, das quais algumas estão expostas na Figura 13. Elas foram extraídas de diferentes seções de imagens maiores. Seis classes de amostras de madeira foram usadas nessa etapa.




Figura 13. Exemplos de diferentes conjuntos de texturas usados na avaliação desse novo índice de fidelidade.

A Tabela 2 apresenta os resultados do índice original (chamado de “Z.Wang”) em comparação ao índice proposto (chamado de “Novo”) quando aplicado a cada linha das amostras de texturas expostas da Figura 13, utilizando valor 2 nos deslocamentos dx e dy usados para o cálculo do histograma da soma.

O comportamento do índice também foi observado numa comparação feita entre as classes. Por exemplo, na comparação da amostra 1 da classe 2 com a amostra 1 da classe 3, o novo índice é igual a 0,0434, o que confirma a diferença.

Tabela 2. Índices de fidelidade aplicados entre as amostras de textura da Figura 13.

| | Amostra 1 para Amostra 2 | | Amostra 1 para Amostra 3 | | Amostra 2 para Amostra 3 | |
|-----------------|--------------------------|-------|--------------------------|-------|--------------------------|-------|
| | Z.Wang | Novo | Z.Wang | Novo | Z.Wang | Novo |
| Classe 1 | -0,066 | 0,975 | -0,089 | 0,924 | -0,065 | 0,941 |
| Classe 2 | 0,024 | 0,671 | -0,051 | 0,776 | -0,104 | 0,748 |
| Classe 3 | 0,004 | 0,976 | -0,042 | 0,947 | -0,014 | 0,958 |

Para o caso da síntese de texturas de papel mostradas na Figura 12, o novo índice Q resultante foi 0,8122, ao invés do -0,0015 atingido por Z.Wang.

A mesma avaliação da perda de informação em JPEG na imagem do *cameraman* da Figura 11, foi repetida com o novo índice. Os resultados desses testes estão expostos na Tabela 3. Da mesma forma, as imagens com diferentes padrões de perda foram comparadas à imagem original e a queda no valor do índice ainda representou a perda de informação nas imagens.

Tabela 3. Resultados do novo índice de fidelidade para as imagens da Figura 11.

| Imagem | Índice Q |
|-------------------------|----------|
| Cameraman 15% | 0,9886 |
| Cameraman 30% | 0,9777 |
| Cameraman 80% | 0,282 |
| Cameraman 90% sobre 80% | 0,1065 |

4.2 Segmentação do filme e da borda da mama

Na maioria dos sistemas de processamento de imagens de mamografias, a primeira fase envolve uma separação entre filme (plano de fundo) e região de interesse – a mama. Como apresentado anteriormente na Seção 2.2, a identificação da borda da mama torna esse processo de extração do filme mais confiável.

Nesse trabalho, a extração do filme e da região da borda da mama foi feita através da aplicação da técnica descrita na Seção anterior dentro de uma mesma imagem. Dessa forma, o novo índice foi utilizado para fazer a classificação de uma mamografia em suas diferentes texturas.

Para essa finalidade, a imagem deve ser subdividida em regiões (janelas) para aplicação do índice. A seguir, a imagem é varrida buscando semelhanças entre as janelas: as janelas são comparadas entre si e a classificação em grupos de texturas é feita com o auxílio de um valor de corte predefinido. Se o índice resultante da comparação entre duas janelas estiver acima desse valor de corte, elas são classificadas como sendo pertencentes a uma mesma textura. Caso contrário, são classificadas como texturas diferentes. Ao fim, a identificação das texturas é representada através da coloração das regiões com cores quaisquer. Cada grupo de textura é representado por uma cor diferente.

A Figura 14 ilustra esses passos. Em (a) a imagem original e em (b) a imagem após a segmentação. É possível notar em (b) a presença dos arcos que delimitam a borda da mama, descritos na Figura 14 (c), que representam as diferentes regiões de diferentes intensidades de incidência da radiação. Como descrito na Seção 2.2, a região da borda da mama encontra-se limitada pelos arcos C e E, onde gradualmente a radiação atravessa uma espessura menor de tecido.




Figura 14. (a) Imagem “mdb014” da base Mini-MIAS, (b) imagem segmentada através do uso do índice de fidelidade e (c) esquema dos arcos que delimitam as regiões atravessadas pela radiação.

O uso desse algoritmo como segmentação em texturas dentro de uma mesma imagem, sofre ajuste de alguns parâmetros, são eles:

- deslocamentos dx e dy do histograma da soma;
- tamanho da janela de comparação;
- limiar de corte para considerar duas regiões como sendo pertencentes ao mesmo grupo de texturas ou não.

Aumentando o limiar de corte, se torna mais difícil que duas texturas sejam consideradas pertencentes a um mesmo grupo. Conseqüentemente aumenta o número de texturas na imagem.

Os melhores valores encontrados para uso nesse trabalho foram de limiar de corte igual a 0,3, deslocamento dx e dy iguais a 1 e janelas de tamanho 15x15 pixels. Esses valores foram encontrados após diversos testes com diferentes tamanhos de janelas, deslocamentos e limiares.

A partir dessa segmentação apresentada, o limite da mama é definido e pode ser automaticamente isolado do resto da mama e conseqüentemente a mama do fundo da imagem.

Para fazer a eliminação também da região da borda, de fora para dentro da região da mama, o sistema elimina as cores que não se apresentam na outra parte da imagem fora desta região. O usuário pode definir o número máximo das cores a serem procuradas. No exemplo de Figura 15, sete cores são eliminadas e as outras são consideradas parte interna da mama. Em (a) a imagem segmentada e em (b) a imagem com a borda da mama retirada.




Figura 15. Mamografia com região da borda da mama eliminada: (a) Imagem resultante da segmentação e (b) imagem final com borda eliminada.

Esse processo de identificação e exclusão da borda através do índice de fidelidade modificado está também apresentado em [8].

Para utilização dessa técnica na base utilizada nesse trabalho (mini-MIAS), a fase de identificação das regiões de texturas apresentou uma particularidade: a região do filme nas imagens tinha uma presença forte de radiação extra-focal. Por esse motivo, após passar pelo processo de segmentação das texturas, a região do filme não aparecia como uma região uniforme, com uma única cor. A Figura 16 traz um exemplo dessa situação.




Figura 16. Em (a) imagem mdb030 original e em (b) a mesma imagem segmentada. Região do filme identificada com mais de uma cor devido à radiação extra-focal alta.

Para reverter esse problema, foi aplicada uma “limiarização” global (*thresholding*) de forma a separar toda a região da mama (inclusive a borda) do filme. Como dito anteriormente, a limiarização não é um método apropriado para esse problema. No entanto, a limiarização nessa fase serviu apenas como pré-processamento para a extração da borda da mama. A Figura 17 mostra exemplos do resultado da limiarização. Dessa forma, é possível eliminar as regiões do filme e só depois eliminar a borda da mama.




Figura 17. Exemplos de limiarização global aplicada às imagens da base Mini-MIAS que possuem 256 cores. A imagem mdb030 em (a) foi limiarizada em (b) com limiar igual a 10. A imagem mdb029 em (c) foi limiarizada em (d) com limiar igual a 5, mostrando os cuidados que devem ser tomados na limiarização já que, nessa imagem, muita informação foi perdida.

A dificuldade na limiarização está em definir o ponto de corte ideal. Um limiar muito baixo pode retornar muito da região do filme, como na Figura 17d. Já um limiar mais alto pode invadir a região da borda da mama. Aliado a isso, o tom de preto do filme das mamografias varia bastante, de modo que um limiar global fixo para todas as imagens não trouxe bons resultados. Então, para encontrar o limiar ideal para as imagens, foi feita uma avaliação prévia da cor predominante no filme e o melhor limiar a ser usado foi encontrado como sendo 4 valores acima desse valor predominante. Assim, o limiar ideal era definido dinamicamente para cada imagem em particular.

Por fim, com o limiar devidamente ajustado, o filme pode ser extraído da imagem e então a borda da imagem pode ser logo depois retirada. Estes passos são ilustrados na Figura 18.




Figura 18. (a) Imagem mdb030 original; (b) imagem segmentada com filme identificado como mais de uma região; (c) limiar global igual a 10 separa o filme da região da mama; (d) imagem com filme homogêneo todo identificado como única cor e (e) imagem com borda da mama extraída.

As partes em cores na imagem são consideradas como região de interesse da imagem. Nesse trabalho, essa região é analisada a fim de identificar os tecidos mamários presentes. Esse é o assunto da próxima seção.

4.3 Segmentação dos tecidos mamários

Para realizar a segmentação da mama em seus tecidos mamários, esta foi novamente subdividida em janelas a serem classificadas de acordo com uma coleção de amostras de imagens de tecidos. Cada uma das janelas foi classificada em um determinado tipo de tecido usando o novo índice de fidelidade descrito anteriormente. Para uma dada janela, a sua classificação era obtida buscando a imagem da coleção de tecidos com maior grau de semelhança com a região da janela. Assim, toda a mama era segmentada de acordo com os tecidos presentes.

Pela própria natureza da mamografia, não é possível extrair uma janela da imagem que contenha apenas um tecido mamário, pois a imagem sempre apresenta sobreposição de tecidos. No entanto, é fácil observar regiões com predominância um tipo de tecido. A partir desse tipo de

observação sobre a base Mini-MIAS, o banco de amostras foi criado. Esse processo está ilustrado na Figura 19, onde janelas das imagens estão em destaque indicando a presença de um tipo de tecido predominantemente. Em (a) está indicado uma amostra de tecido adiposo sendo colhida. Da mesma forma, em (b) uma amostra de tecido glandular e em (c) uma amostra de tecido glandular denso. Um detalhe a considerar é que as amostras em destaque representam, na realidade, uma mistura de tecido glandular e fibroso. Mas, como o tecido fibroso existe em menor quantidade, as regiões são consideradas apenas como tecido glandular.

Para construção de um banco de amostras que representasse bem todas as variações dos tecidos, 96 imagens foram separadas das quais as amostras foram extraídas. Dessas 96 imagens, 183 amostras com 120x120 pixels ao todo foram colhidas, separadas da seguinte forma:

- 49 amostras de tecido adiposo (26,78% do total de amostras);
- 66 amostras de tecido glandular (36,06%);
- 68 amostras de tecido glandular denso (37,16%).

Ainda, uma amostra do filme foi adicionada ao banco para classificação dessa região. Para a integração com a etapa anterior de segmentação da borda da mama, a região já identificada como filme era automaticamente mapeada para preto.




Figura 19. Seleção de amostras dos tecidos nas mamografias. (a) mdb060 – amostra de tecido adiposo; (b) mdb50 – amostra de tecido glandular e (c) mdb172 – amostra de tecido glandular denso.

Como é possível ver na Figura 19, em termos gerais, o tecido adiposo aparece escuro na imagem, e aparece como uma região homogênea. Já o tecido glandular aparece como uma região heterogênea, onde na maioria das vezes é possível vê-lo com aspecto de fibras, mais clara que o tecido adiposo. Já o tecido glandular denso, aparece como uma região toda clara, sendo característico de pacientes jovens.

Como dito anteriormente, o índice de fidelidade retorna um valor entre -1 e 1, avaliando a similaridade entre duas imagens. As janelas na mamografia são classificadas como sendo pertencentes à mesma classe da amostra que obtiver maior valor de índice dentre todas as comparações. Dessa maneira, cada janela na mamografia é classificada entre tecido adiposo, glandular ou glandular denso. Alguns resultados estão apresentados na Figura 20. A legenda de cores indica qual cor corresponde a cada tipo de tecido. Eles apresentam variação no tamanho da janela de comparação e em todos foram utilizados deslocamentos dx e dy do histograma da soma igual a 1.

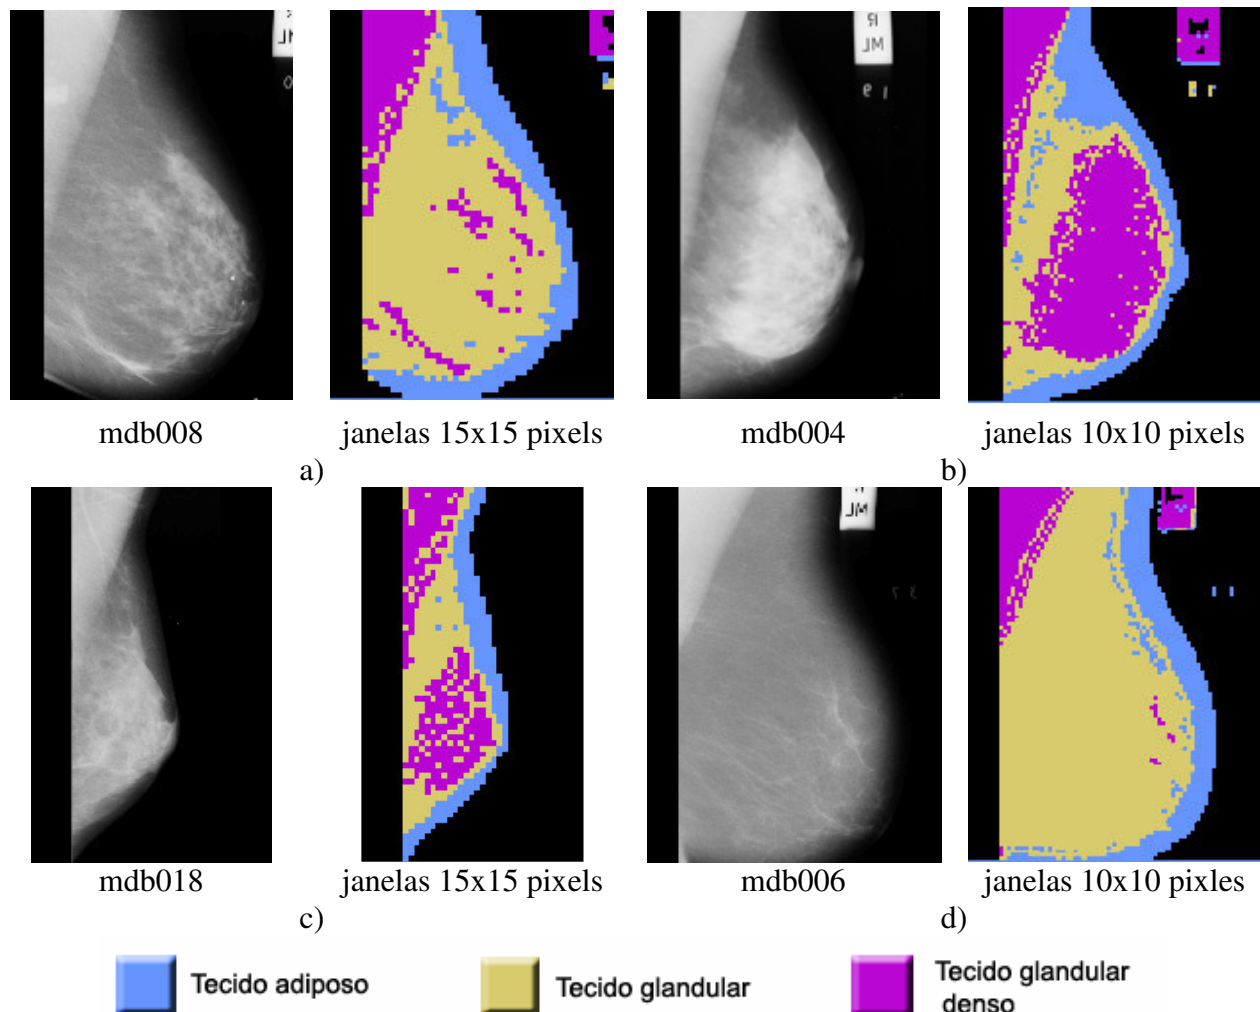


Figura 20. Exemplos da segmentação da mamografia em tecidos adiposo, glandular, e glandular denso.

É possível ver nas imagens segmentadas que a borda da mama foi sempre corretamente classificada como tecido adiposo. Da mesma forma, as regiões de tecido glandular e glandular denso também foram identificadas, apresentadas nas mamografias com regiões mais claras.

Um ponto a observar é que, embora não faça parte do tecido mamário, o músculo da paciente é visível na mamografia (parte superior esquerda) e também acaba sendo classificada pelo algoritmo. Por semelhança de textura, ela é sempre classificada como tecido glandular denso. O ideal nessa situação seria um outro processamento para identificar essa região de músculo. No entanto, essa atividade foge do escopo desse trabalho e está sugerida como trabalho futuro.

O impacto da variação do tamanho da janela e dos deslocamentos dx e dy do histograma da soma sobre o resultado da segmentação foi avaliado através de uma série de testes. Para todas as variações, os resultados apresentaram-se muito estáveis sob a essas variações. O uso de janelas menores (10x10 pixels) torna o aspecto da segmentação melhor, por reduzir a impressão das janelas quadradas na imagem. Por outro lado, é mais custoso por aumentar o processamento, deixando o algoritmo mais lento.

4.3.1 Testes com amostras de doenças

O comportamento do algoritmo descrito anteriormente foi avaliado também para fins de identificação de doenças nas mamografias. Para isso, foram selecionadas amostras de lesões e adicionadas ao banco de amostras já construído. No entanto os resultados não foram satisfatórios apresentando um grande número de falsos positivos.

A base mini-MIAS contém em sua documentação as coordenadas do local da lesão na imagem e seu respectivo raio. A base separa as anomalias em 6 classes:

1. CALC: calcificações
2. ARCH: “Distorção arquitetural” (*architectural distortion*).
3. ASYM: assimétrico
4. MISC: outros ou sem definição
5. CIRC: circunscrito
6. SPIC: “espiculado”

A Figura 21 apresenta um exemplo de cada uma dessas classes.




Figura 21. Anomalias presentes em mamografias divididas em 6 classes da base mini-MIAS

Os tumores malignos normalmente possuem contornos irregulares ou espiculados [11], por isso é importante diferenciar o contorno da lesão.

As amostras usadas para compor o banco foram retiradas e classificadas de acordo com essa divisão da base mini-MIAS utilizando as informações das coordenadas e raio da lesão. A classe CALC, referente às calcificações, indica *clusters* de calcificações presente nas imagens.

Com exceção da borda da mama que foi identificada corretamente, todos os resultados desses testes foram insatisfatórios, com alto número de falsos positivos mesmo diante da variação dos deslocamentos do histograma da soma.

Além desses testes, uma segunda análise foi feita sobre as classes das amostras para avaliar a distinção entre elas através do índice de fidelidade. Para isso, todas as amostras de anomalias foram comparadas entre si de duas formas: internamente a cada classe e entre elas.

A Tabela 4 apresenta a média e desvio padrão dos índices de fidelidade (aplicado ao histograma da soma) encontrados nas comparações entre as amostras dentro de uma mesma classe.

Tabela 4. Comparações entre amostras de uma mesma classe, onde CALC = calcificações; ARCH = Distorção arquitetural; ASYM = assimétrico; MISC = outros ou sem definição; CIRC = circunscrito; SPIC: “espículado”.

| Classe | Média | Desvio Padrão |
|--------|----------|---------------|
| ARCH | 0,23599 | 0,31591 |
| ASYM | 0,10075 | 0,20093 |
| CALC | 0,095285 | 0,20111 |
| CIRC | 0,17669 | 0,24146 |
| MISC | 0,24074 | 0,26142 |
| SPIC | 0,10782 | 0,18207 |

Como esperado, o valor médio dos índices foi razoavelmente baixo para todos os casos, pois as imagens divergem visualmente mesmo dentro de uma classe. No entanto, em todos os casos, a média se apresentou maior que 0. É possível observar ainda que a classe MISC apresentou maior semelhança entre as amostras trazendo maior média. Ainda, a classe CALC apresentou menor média, representando menor semelhança entre as amostras.

A Tabela 5 apresenta os resultados das comparações entre amostras de classes diferentes. Para cada duas classes comparadas, é exibida a média e o desvio padrão dos índices de fidelidade encontrados. Por esses resultados, é possível ver que os pares “CIRC e MISC” e “ARCH e MISC” apresentaram maior semelhança quando o índice Q é utilizado. Uma outra observação a ser feita é sobre a classe CALC, que contém amostras de calcificações. Esta apresentou um valor médio baixo de índice em comparação com todas as outras classes (média < 0,1) sendo os menores valores médios.

Tabela 5. Comparação de amostras entre classes, onde CALC = calcificações; ARCH = Distorção arquitetural; ASYM = assimétrico; MISC = outros ou sem definição; CIRC = circunscrito; SPIC: “espículado”.

| Classe 1 | Classe 2 | Média | Desvio padrão |
|----------|----------|----------|---------------|
| ARCH | ASYM | 0,1307 | 0,19744 |
| ARCH | CALC | 0,07097 | 0,15702 |
| ARCH | CIRC | 0,18601 | 0,22943 |
| ARCH | MISC | 0,18983 | 0,22578 |
| ARCH | SPIC | 0,16134 | 0,22852 |
| ASYM | CALC | 0,050429 | 0,16409 |
| ASYM | CIRC | 0,1379 | 0,21125 |
| ASYM | MISC | 0,18072 | 0,23334 |
| ASYM | SPIC | 0,13185 | 0,21495 |
| CALC | CIRC | 0,079491 | 0,17419 |
| CALC | MISC | 0,072866 | 0,18624 |
| CALC | SPIC | 0,059869 | 0,15873 |
| CIRC | MISC | 0,19195 | 0,24199 |
| CIRC | SPIC | 0,14872 | 0,21911 |
| MISC | SPIC | 0,16256 | 0,23235 |

4.3.2 Testes com uso do LBP

Assim como no histograma da soma, o índice de Z.Wang foi aplicado ao LBP (*Local Binary Pattern*) para analisar o desempenho do índice sobre esse outro descritor de textura. Os resultados dessa aplicação não foram significativos ao ponto das regiões na mamografia não serem sequer distinguidas. Alguns desses resultados estão expostos na Figura 22. Como é possível observar, a imagem foi quase completamente confundida com região de filme.




Figura 22. (a) Imagem mdb002 e (b) resultado da segmentação utilizando o LBP.

Como descrito anteriormente, o cálculo do histograma LBP é feito comparando cada pixel existente na imagem com cada um dos oito pixels vizinhos para construção de uma matriz binária e posterior multiplicação pela matriz de pesos.

Como dito na Seção 3.1, o problema do LBP é que ele atribui um peso muito alto a algumas das posições da matriz de pesos e também não leva em consideração nenhuma informação sobre as cores em si dos pixels, apenas do relacionamento entre eles.

Para atender essas deficiências, uma modificação foi proposta ao LBP. Para resolver o problema dos altos pesos atribuídos a algumas posições, a modificação proposta consiste em adicionar novas matrizes de pesos de modo a equilibrar o peso de cada posição. A Figura 23 apresenta tais matrizes. Em (a) a matriz de pesos original apresentada anteriormente. Em (b), (c) e (d), as matrizes rotacionadas.




Figura 23. Novas matrizes de pesos do LBP. Em (a) matriz original e em (b), (c) e (d) as matrizes rotacionadas.

O cálculo do histograma LBP com as novas matrizes de pesos é feito simplesmente calculando a média aritmética dos resultados individuais com as 4 matrizes. Para o exemplo da Figura 24 o resultado seria: $169 + 228 + 149 + 39 = 585/4 = 146$. Dessa forma, o valor 146 do histograma LBP deve ser incrementado de 1. Assim, os 8 vizinhos recebem mesmo peso.

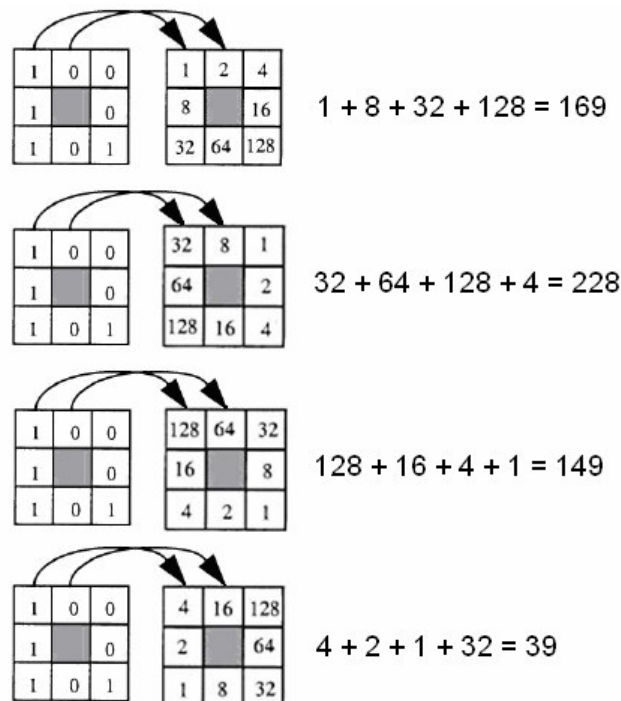


Figura 24. Cálculo do LBP com as novas matrizes.

Para resolver o problema da falta de informação sobre as cores da imagem, uma segunda modificação consiste em adicionar ao valor do LBP algum elemento que represente a(s) cor(es) da região sendo analisada. Duas abordagens foram testadas:

- adição da cor do pixel central da janela da imagem;
- adição da média aritmética dos 9 pixels da janela da imagem.

Esse valor, adicionado ao valor encontrado após cálculo do valor do LBP das 4 matrizes rotacionadas, passa a compor um histograma que varia de 0 a 512. A Figura 25 traz exemplos dessa modificação sendo aplicada à mamografia para a classificação junto ao índice de fidelidade utilizando janelas de 20x20 pixels.

Como observado na Figura 25, o resultado encontrado com a adição do valor da média dos pixels da janela foi mais significativo, aproximando-se mais do resultado do histograma da soma e identificando os diferentes tecidos mamários. No entanto, a região de tecido adiposo ainda foi confundida com o filme. Formas de melhorar esses resultados ainda podem ser discutidas, mas estão sugeridas como trabalho futuro.




Figura 25. Experimentos utilizando o índice de fidelidade aplicado ao LBP com 4 matrizes rotacionadas e janelas de 20x20 pixels. Em (a) imagem original mdb002. Em (b) LBP somado ao pixel central e em (c) somado à média dos 9 pixels da janela.

4.3.3 Testes com uso da GLCM

O desempenho do índice na segmentação dos tecidos mamários foi ainda avaliado na aplicação com um terceiro descritor de textura: a GLCM. Como dito anteriormente, esse descritor apresenta uma boa informação sobre a distribuição de cores na textura original e por isso tem sido bastante utilizado na maioria dos trabalhos que envolvem análise de texturas.

A Figura 26 apresenta um dos resultados dessa aplicação. Os resultados desses testes mostraram-se semelhantes aos resultados obtidos com uso do histograma da soma.




Figura 26. Resultado da aplicação do índice de fidelidade à matriz GLCM na imagem mdb002 com janelas de 20x20 pixels.

É importante ressaltar o alto custo computacional associado ao uso da GLCM, já que qualquer processamento utilizando o descritor tem de operar sobre uma matriz com 256x256 elementos, ao invés de um único vetor com no máximo 512 posições, como nos casos anteriores. Isso interferiu bastante na velocidade de processamento das mamografias através do índice de fidelidade. Foi necessário aproximadamente 1000 vezes mais tempo para processar uma imagem através da GLCM do que usando o histograma da soma. Isso dificultou a realização dos testes, tornando a GLCM uma opção muito cara computacionalmente para uso com o índice.

4.4 Testes com redes neurais de aprendizado não-supervisionado

As Redes Neurais Artificiais (RNAs) são sistemas compostos por unidades de processamento que calculam determinadas funções matemáticas a fim de armazenar conhecimento e utilizá-lo. Na construção de tais sistemas, é possível obter uma regra para distinguir classes de dados através de uma *fase de treinamento* da rede. RNAs têm a capacidade de aprender através de exemplos previamente observados. Assim é possível generalizar a informação aprendida para exemplos não-conhecidos. Esse tipo de modelagem computacional relembra, em algum nível, a estrutura do cérebro humano.

Durante a fase de treinamento a rede extrai as informações relevantes dos dados apresentados para ela, criando uma representação para o problema. Um *algoritmo de aprendizado* consiste em um conjunto de procedimentos para ajustar uma RNA para que a mesma possa “aprender” uma determinada função.

Diversos métodos para treinamento de redes foram desenvolvidos, podendo ser agrupados em dois paradigmas principais: aprendizado supervisionado e aprendizado não-supervisionado.

O aprendizado supervisionado é o método mais comum no treinamento de redes. Possui esse nome porque a entrada e a saída desejada para a rede são fornecidas durante o treinamento.

No aprendizado não-supervisionado somente os padrões de entrada estão disponíveis para a rede. A partir desses dados, a rede é capaz de formar representações internas para codificar características da entrada e criar novas classes ou grupos automaticamente.

Como forma de avaliar outros métodos de segmentação em mamografias, duas redes neurais de aprendizado não-supervisionado foram utilizadas: o Mapa Auto-Organizável de Kohonen [23] e o K-Médias [23]. A ferramenta utilizada para os testes das redes foi a AnImed [24], software para análise de imagens médicas e biológicas.

As redes SOM de Kohonen (*Kohonen's Self-Organizing Maps*) são baseadas no aprendizado competitivo, onde os neurônios competem entre si para serem ativados. A unidade vencedora conseqüentemente terá o direito de atualizar seus pesos. Quando um padrão de entrada é apresentado, a rede procura a unidade mais parecida com esse padrão. Durante o treinamento, a rede aumenta a semelhança do nodo escolhido e de seus vizinhos a esse padrão de entrada. Desta forma, a rede constrói um mapa topológico onde nodos que estão topologicamente próximos respondem de forma semelhante a padrões de entrada semelhantes [25].

A Figura 27 apresenta alguns resultados obtidos através da segmentação da mamografia utilizando as redes de Kohonen. Cada cor indica uma região diferente. O algoritmo sofre ajuste da quantidade de classes desejadas, do número de iterações e da taxa de aprendizado. A Figura ilustra a variação da quantidade de classes de 5 a 25, com número de iterações e taxa de aprendizado fixados em 50 e 0,1, respectivamente. Da esquerda para a direita o nível de detalhamento dos tecidos aumenta devido ao aumento do número de classes. Os contornos minimamente definidos das regiões ocorrem, pois essa é uma abordagem pixel-a-pixel.

Os resultados encontrados permitiram ver as redes SOM como uma boa ferramenta para segmentação de mamografias. É interessante observar que, com o aumento do número de classes, cresce também o número de faixas presentes na borda da mama, semelhante aos resultados apresentados na Seção 4.2. Ainda, com a variação da quantidade de classes, é possível ajustar o nível de detalhamento do tecido desejado. Por exemplo, para um número pequeno de classes, tal qual mostrado na Figura 27b, é possível identificar as regiões do músculo, da borda da mama, do tecido adiposo e tecido glandular. Com quantidades altas de classes, cresce o nível de detalhamento, sendo possível identificar estruturas como veias sanguíneas e dutos além de melhorar a definição dos contornos das regiões (Figura 27d).

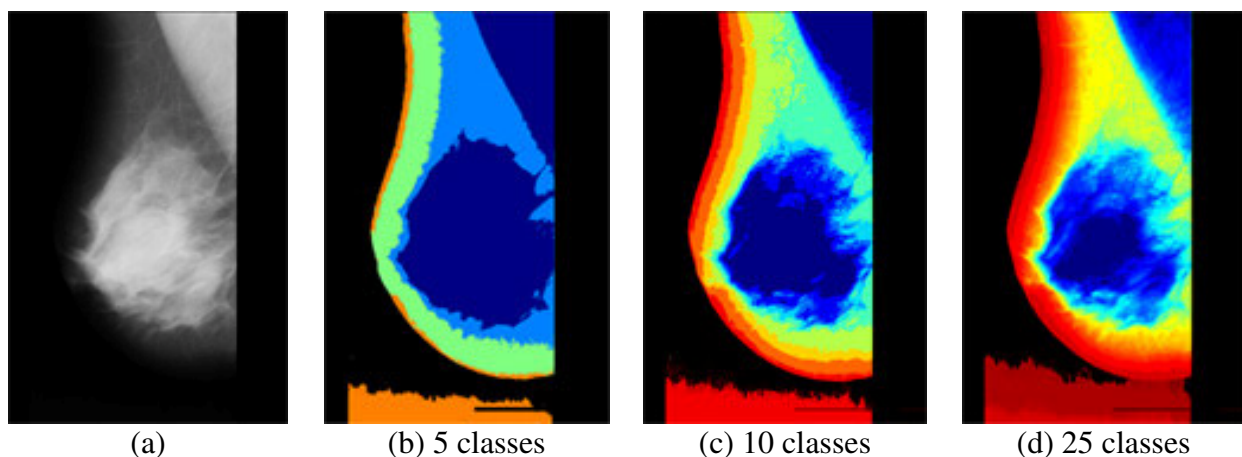


Figura 27. Resultados da segmentação de mamografias utilizando os mapas auto-organizáveis de Kohonen: em (a) imagem mdb001 original. Em (b) a segmentação com 5 classes, em (c) com 10 classes e em (d) com 25 classes. O número de iterações e a taxa de aprendizado foram fixados em 50 e 0,1, respectivamente.

Isso é importante do ponto de vista de identificação de doenças. Por exemplo, para fins de análise de calcificações, é de grande importância a distinção entre calcificações arteriais e ductais, pois o grau de risco associado a cada uma delas é diferente. Já no caso de nódulos, a discriminação do seu formato é uma tarefa de rotina para os radiologistas, já que tumores com formato espiculado têm maior chance de serem malignos [11]. Esse fato está ilustrado na Figura 28 onde a rede SOM de Kohonen foi utilizada para segmentar regiões de tumores nas mamografias. Em (a) o recorte de um tumor benigno presente na imagem mdb015 da classe CIRC e em (b) a sua segmentação usando 5 classes. Observa-se que a segmentação enfatiza seu formato circunscrito. Em (c) o recorte de um tumor maligno da classe SPIC original da imagem mdb181 e em (d) sua segmentação com 5 classes. Também nesse caso, a segmentação enfatiza o contorno, dessa vez espiculado (espinhado), característico dos casos malignos.




Figura 28. Segmentação de tumores através de rede SOM: (a) Tumor benigno da classe CIRC; (b) 5 classes; (c) Tumor maligno da classe SPIC e (d) 5 classes.

O segundo algoritmo de aprendizado não-supervisionado usado nos testes foi o algoritmo de agrupamento de K-Médias. Esse algoritmo reparte o conjunto fornecido de pontos de dados em subgrupos, cada um dos quais sendo tão homogêneo quanto possível, ou seja, com características similares entre si. Podemos ilustrar isso na Figura 29, onde um conjunto de entrada de 8 dados com 2 atributos é rotulado considerando-se um número de médias $k = 2$.




Figura 29. Conjunto de dados de entrada rotulado em duas classes definindo-se $k = 2$.

O K-Médias apresentou-se como uma boa opção para a segmentação das mamografias. Não foram encontradas diferenças entre os resultados exibidos pelo K-Médias e aqueles obtidos com as redes SOM. A Figura 30 apresenta alguns desses resultados. Essa rede apresentou-se como uma opção menos custosa computacionalmente com resultado equivalente ao da rede SOM que possui um algoritmo mais complexo. É interessante observar na Figura 30c a presença de um tumor benigno, indicado pela seta. Na versão segmentada dessa imagem (Figura 30d) é possível observar o destaque dessa região.

Um ponto a destacar é que, por terem abordagens pixel-a-pixel, a precisão obtida por esses algoritmos no contorno das margens entre as regiões é bastante satisfatório. Isso é uma vantagem em relação ao método utilizado anteriormente para utilização do índice de fidelidade. Como forma de melhorar a fase de identificação dos tecidos previamente apresentada, uma alternativa seria utilizar a rede K-Médias ou a rede SOM para usufruir da boa segmentação das regiões para, a seguir, efetuar a classificação dessas regiões em seus diferentes tecidos mamários através do índice de fidelidade. Essa atividade está exposta como trabalho futuro no último Capítulo desta monografia.

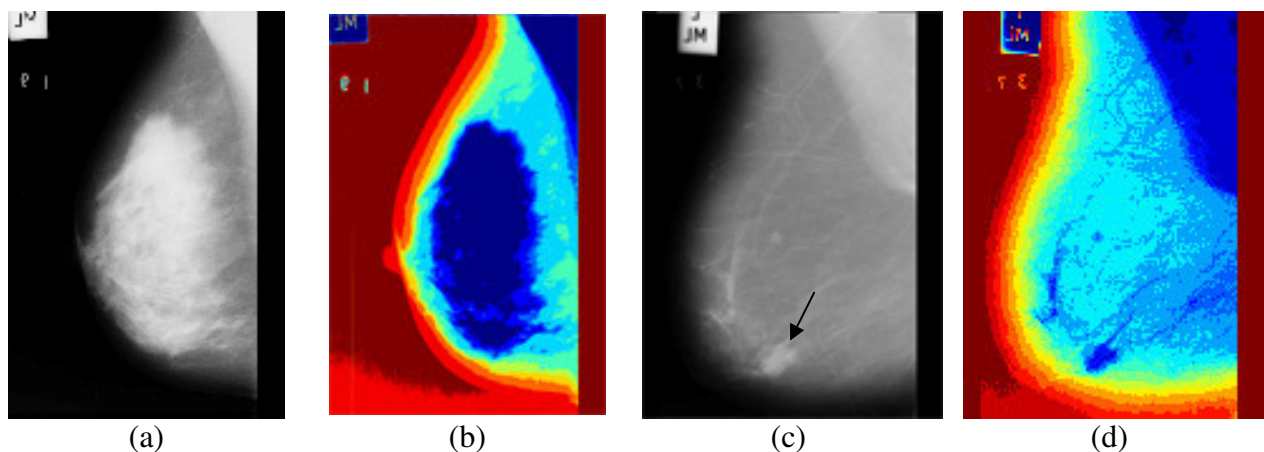


Figura 30. Exemplos de aplicação do algoritmo K-Médias às imagens de mamografias utilizando 15 classes, 50 iterações e taxa de aprendizado igual a 0,1. (a) Imagem mdb003 e (b) 15 classes encontradas para essa imagem; (c) imagem mdb005 e (d) as 15 classes encontradas para essa imagem.

Capítulo 5

Conclusões e Trabalhos Futuros

A análise de imagens de mamografias é uma tarefa difícil mesmo para radiologistas experientes. As ferramentas CAD vêm tentando auxiliar a interpretação das informações contidas nas mamografias através do computador e várias técnicas foram desenvolvidas ao longo dos últimos anos. Em vários trabalhos, o uso de atributos de texturas tem sido citado como uma boa maneira de avaliar regiões, mas muito estudo ainda precisa ser realizado. Por envolver mais de uma área de conhecimento (a Computação e a Medicina), o fluxo das informações é mais lento e grande parte das conclusões são obtidas sem muito entendimento do objeto de estudo, apenas de forma empírica utilizando algoritmos de propósito geral.

5.1 Contribuições

Este trabalho procurou avaliar o uso de algumas técnicas durante a análise de imagens mamográficas. Em especial, um descritor de texturas foi utilizado como um elemento de análise da distribuição de cores em uma imagem. Ele foi aplicado no índice de fidelidade de Z.Wang previamente definido. Este novo índice tem as mesmas vantagens que o de Z.Wang como, por exemplo, ele pode ser aplicado a imagens JPEG com diferentes perdas. Além disso, essa variação é mais adequada para a análise de texturas de uma imagem onde a avaliação pixel a pixel não é suficiente.

Esse novo índice foi usado na segmentação de mamografias. Primeiramente, o uso do índice comparando regiões dentro de uma mesma imagem permitiu o isolamento da região da borda da mama e do filme. Nessa etapa, foi observada presença da radiação extra-focal bastante evidente em muitas imagens da base utilizada nos experimentos. Por isso uma limiarização foi realizada adicionalmente. No entanto, a correta identificação da borda não sofreu interferência.

Ainda, o índice apresentou-se como um bom método para distinguir regiões de tecidos mamários diferentes. Ele foi usado para segmentar e classificar as mamografias. A classificação ocorreu através da avaliação da similaridade entre as regiões da mamografia e das amostras do banco de imagens de tecidos mamários construído. Essa classificação apresentou bom desempenho na distinção das regiões. A única limitação dessa abordagem está no uso de janelas de comparação quadradas, tornando o aspecto da segmentação pouco natural para imagens médicas. Por esse motivo, o uso de janelas de tamanho pequeno torna a visualização do resultado mais atrativa.

Como forma de avaliar o uso do índice na distinção de anomalias, foram realizados experimentos envolvendo amostras de lesões mamárias. Inicialmente, tais amostras foram incluídas no banco usado para classificação das mamografias. Pela dificuldade natural do problema, o desempenho dessa segunda classificação foi insatisfatório, trazendo um grande número de falsos positivos. No entanto, este atualmente é um problema sem boas soluções, principalmente na identificação de tumores.

Uma segunda análise foi feita comparando as amostras entre si, considerando as classes a que pertencem. Tanto os resultados da comparação entre amostras de uma mesma classe quanto de classes diferentes foram pouco significativos, indicando pouca representatividade do índice na distinção entre as classes de anomalias. No geral, os resultados da comparação entre classes diferentes indicaram a classe de calcificações como mais distinta das demais classes de tumores. Ainda foi possível observar que os resultados da comparação entre classes apresentaram valores mais baixos que o da comparação de amostras de uma mesma classe. Isto é, no geral, os valores dessa segunda comparação indicam que as amostras são mais distintas do que as amostras comparadas anteriormente. Esse é um resultado pouco conclusivo, mas, devido a grande variação das texturas e formato das anomalias nas amostras, pode ser considerado um resultado positivo.

Para analisar o desempenho de um outro descritor de textura, o histograma da soma foi substituído pelo LBP, um descritor em formato de histograma que leva em consideração apenas o relacionamento local entre os pixels, sem nenhuma informação sobre as cores em si. Para o caso da segmentação de tecidos, o LBP não foi suficiente para descrever as texturas de modo distinguir as regiões através do índice. Isso pode decorrer da ausência de informação sobre as cores na imagem e também pela ponderação muito irregular na matriz de cálculo do LBP. De acordo com a matriz de pesos que é utilizada no cálculo, alguns elementos têm mais impacto no valor final obtido no cálculo. Uma modificação realizada no LBP consistiu em adicionar novas matrizes de pesos para distribuir uniformemente o impacto de cada posição da matriz. Para inserir a informação de cor necessária, foi adicionada a média das cores dos pixels. Essa nova versão do histograma LBP apresentou resultados bem mais representativos durante a classificação dos tecidos nas mamografias.

O desempenho de outro descritor de textura ainda foi verificado sob uso junto ao índice: a GLCM. Esse descritor, vastamente utilizado nas principais contribuições científicas envolvendo análise de texturas, apresentou resultado satisfatório na descrição dos tecidos mamários. Ele aproximou-se da segmentação obtida por meio do histograma da soma. O grande problema do uso da GLCM decorreu do alto custo computacional, tornando o processamento das imagens extremamente lento. Isso confirmou o uso do histograma da soma como uma boa opção a baixo custo.

Uma outra etapa de experimentos envolveu o uso de redes neurais de aprendizado não-supervisionado para segmentação das mamografias. A aplicação dos Mapas Auto-Organizáveis de Kohonen e do algoritmo de agrupamento K-Médias apresentaram resultados atrativos e aparentemente sem distinção entre os dois. Por terem abordagem pixel-a-pixel, tais algoritmos mostraram uma segmentação com um bom nível de detalhamento dos tecidos, sendo possível observar, por exemplo, os formatos de lesões presentes nas imagens que é de grande importância para o diagnóstico.

Este trabalho também contribuiu com a publicação de um artigo científico na Conferência Latino-Americana de Informática em 2006 (CLEI 2006), realizada no Chile.

5.2 Trabalhos Futuros

Para uma melhor avaliação do novo índice de fidelidade na distinção entre as lesões mamárias, novos testes podem ser realizados. Como as amostras foram colhidas utilizando o raio da lesão descrito na base, muitas vezes o corte da imagem não permite visualizar o contorno da lesão nem do tecido ao redor da anomalia, o qual pode ter valor descritivo que auxilie nessa tarefa. Além disso, a grande quantidade de falsos positivos encontrados na classificação das mamografias utilizando o banco com as amostras de doenças, tal como os resultados pouco conclusivos da comparação entre as amostras, pode ter ocorrido devido ao uso de amostras pouco representativas. Um trabalho futuro sugerido é a melhor avaliação da representatividade das amostras do banco de doenças, possivelmente excluindo algumas amostras e aumentando o raio de corte da lesão. Essa análise de representatividade pode ser verificada com a construção de uma ferramenta de recuperação de imagens baseada em conteúdo (CBIR – *Content Based Image Retrieval*) [6], utilizando as imagens das lesões. Dessa forma é possível avaliar a taxa de acerto na classificação das amostras, avaliando também o uso de outros descritores de texturas como o LBP.

Sobre o LBP, novas formas de melhorar a sua descrição das texturas podem ser estudadas para uso junto ao índice de fidelidade. Tentando inserir informações sobre as cores na imagem de outras maneiras, ou testando novas formas de balancear os pesos da matriz de pesos do LBP.

Acerca de segmentação dos tecidos, uma etapa de pré-processamento pode ser desenvolvida para identificar a região do músculo na mamografia.

Em relação à segmentação dos tecidos, as redes neurais de aprendizado não-supervisionado apresentam uma solução para o problema do método utilizado nesse trabalho através do índice. A pouca naturalidade e baixa precisão na subdivisão das regiões utilizando janelas quadradas podem ser resolvidas utilizando uma dessas redes neurais. Para isso, o uso das redes seria usado como uma etapa de pré-processamento apenas para segmentar as regiões de acordo com o nível de detalhamento desejado. Logo após, a classificação seria realizada através do índice de fidelidade comparando as regiões já segmentadas com as amostras do banco. Além disso, o estudo do uso dessas redes na identificação dos contornos das lesões mamárias pode ser aprofundado.

Bibliografia

- [1] American Cancer Society. Disponível em: <<http://www.cancer.org>>. Acesso em 14 de setembro de 2007.
- [2] MELLO-THOMS, C. Perception of Breast Cancer: Eye-Position Analysis of Mammogram Interpretation, *Academic Radiology*, v.10, 2003.
- [3] SANTO, M.; MOLINARA, M.; TORTORELLA, F; VENTO, M. Automatic Classification Of Clustered Microcalcifications By A Multiple Expert System. *Pattern Recognition*, v. 36, p. 1467-1477, 2003.
- [4] BOVIS, K.; SINGH, S. Detection of Masses in Mammograms Using Texture Features. *Proceedings. 15th International Conference on Pattern Recognition*. v. 2, p. 267-270, Barcelona, 2000.
- [5] MARTINS, L. *et al.* Classification of Normal, Benign and Malignant Tissues Using Co-occurrence Matrix and Bayesian Neural Network in Mammographic Images. *Ninth Brazilian Symposium on Neural Networks (SBRN '06)*, p.5, Ribeirão Preto, 2006.
- [6] WEI, C.; LI, C.; ROLAND, W. A Content-Based Approach to Medical Image Database Retrieval. *Database Modelling for Industrial Data Management: Emerging Technologies and Applications*. Pennsylvania: Ma Z, p. 258–292, 2005.
- [7] MELLO-THOMS, C. *et al.* Interactive Computer-Aided Diagnosis of Breast Masses: Computerized Selection of Visually Similar Image Sets From a Reference Library. *Academic Radiology 2007*. v. 14, p. 917– 927.
- [8] MELLO, C.; MASCARO, A. Image Fidelity Index Applied to Digital Mammography Texture Segmentation. *XXXII Conferência Latinoamericana de Informática - CLEI 2006*, Santiago, 2006.
- [9] WANG, Z., BOVIK, A.; LU, L. Why is image quality assessment so difficult?, *IEEE International Conference on Acoustic, Speech and Signal Processing (ICASSP) 2002*, Flórida, p. 3313-3316, 2002.
- [10] Instituto Nacional de Câncer (INCA). Disponível em: <<http://www.inca.gov.br>>. Acesso em 28 de outubro de 2007.

- [11] HIGHNAM, R.; BRADY, M. Mammographic Image Analysis. Computational Imaging and Vision. 1. ed. Dordrecht, Boston, Londres: Kluwer Academic Publishers, 1999. 392 p.
- [12] ZHENG, B. *et al.* Actual Versus Intended Use of CAD Systems in The Clinical Environment. Proceedings of SPIE 2006; v. 6146, p. 9–14, 2006.
- [13] FREER, T.; ULISSEY, M. Screening Mammography with Computer-Aided Detection: Prospective Study of 12,860 Patients in A Community Breast Center. Radiology, v. 220. p. 781–786, 2001.
- [14] BOTTEMA, M.; SLAVOTINEK, J. Detection and Classification of Lobular And DCIS (Small Cell) Microcalcifications In Digital Mammograms. Pattern Recognition Letters, v. 21. p. 13-14, 2000
- [15] AYLWARD, S.; HEMMINGER, B.; PISANO, E. Mixture Modeling for Digital Mammogram Display and Analysis. Digital Mammography, Computational Imaging and Vision Series, v. 13, p. 305-312, 1998.
- [16] MELLO, C.. *Synthesis of Images of Historical Documents for Web Visualization*. IEEE Multimedia Modelling, 2004, Brisbane, 2004.
- [17] HARALICK, R. *et al.* Textural Features for Image Classification. IEEE Transactions on Systems, Man and Cybernetics, p. 610–621, 1973.
- [18] TOURASSI, G. Journey toward computer-aided diagnosis: Role of Image Texture Analysis. Radiology, v. 213, n.2, p. 317-320, 1999.
- [19] CHENG, D.; CUI, M. Mass Lesion Detection with A Fuzzy Neural Network. Pattern Recognition, v. 37. n. 6 , p.1189-1200, 2004.
- [20] OJALA, T.; PIETIKÄINEN, M., Unsupervised Texture Segmentation Using Feature Distributions. Pattern Recognition. v. 32, n. 3, p. 477-486, 1999.
- [21] SUCKING, J. *et al.* The Mammographic Image Analysis Society Digital Mammogram Database Exerpta Medica. International Congress Series 1069, p. 375-378. 1994.
- [22] Matlab em: <http://www.mathworks.com/>. Acesso em 26 de novembro de 2007.
- [23] HAYKIN, S. Redes Neurais: Princípios e Práticas. 2. ed. Porto Alegre: Bookman, 2001.
- [24] SANTOS, W. Análise de Imagens Digitais em Patologia utilizando Morfologia Matemática e Lógica Nebulosa. 2003. Dissertação de Mestrado em Engenharia Elétrica, Universidade Federal de Pernambuco - UFPE, Recife.
- [25] BRAGA, A.; CARVALHO, André; LUDERMIR, Teresa. Redes Neurais Artificiais – Teoria e Aplicações. 1. ed. Rio de Janeiro: LTC, 2000. 262 p.